주성분 분석법과 선형판별 분석법을 이용한 최적화된 방사형 기저 함수 신경회로망 분류기의 설계

Design of Optimized Radial Basis Function Neural Networks Classifier with the Aid of Principal Component Analysis and Linear Discriminant Analysis

김옥동 · 오성권[†]

Wook-Dong Kim and Sung-Kwun Oh[†]

수원대학교 전기공학과

Department of Electrical Engineering, The University of Suwon

요 약

본 연구에서는 주성분 분석법 및 선형 판별 분석법을 이용한 다항식 방사형 기저 함수 신경회로망 분류기의 설계 방법론을 소개한다. 주성분 분석법과 선형판별 분석법을 사용하여 주어진 데이터의 정보 손실을 최소화한 특징데이터를 생성하고 이를 다항식 방사형 기저함수 신경회로망의 입력데이터로 사용한다. 방사형 기저 함수 신경회로망의 은닉층은 FCM 클러스터링 알고리즘으로 구성되며 연결가중치는 1차 선형식을 사용하였다. 최적의 분류기 설계를 위해서 최근에 제안된 Artificial Bee Colony(ABC) 최적화 알고리즘을 사용하여 구조 및 파라미터를 동조하였다. ABC 알고리즘을 통해 주성분 분석법과 선형판별 분석법의 고유벡터의 수 및 FCM 클러스터링 알고리즘의 퍼지화 계수등의 파라미터를 동조한다. 제안된 분류기는 대표적인 Machine Learning(ML) 데이터를 사용하여 성능을 평가하며 기존 분류기와 성능을 비교한다.

키워드 : 방사형 기저 함수 신경회로망, 주성분 분석법, 선형판별 분석법, Artificial Bee Colony, FCM 클러스터링

Abstract

In this paper, we introduce design methodologies of polynomial radial basis function neural network classifier with the aid of Principal Component Analysis(PCA) and Linear Discriminant Analysis(LDA). By minimizing the information loss of given data, Feature data is obtained through preprocessing of PCA and LDA and then this data is used as input data of RBFNNs. The hidden layer of RBFNNs is built up by Fuzzy C-Mean(FCM) clustering algorithm instead of receptive fields and linear polynomial function is used as connection weights between hidden and output layer. In order to design optimized classifier, the structural and parametric values such as the number of eigenvectors of PCA and LDA, and fuzzification coefficient of FCM algorithm are optimized by Artificial Bee Colony(ABC) optimization algorithm. The proposed classifier is applied to some machine learning datasets and its result is compared with some other classifiers.

Key Words : Radial Basis Function Neural Networks, Principal Component Analysis, Linear Discriminant Analysis, Artificial Bee Colony, Fuzzy C-Means Clustering.

1. 서 론

접수일자: 2012년 3월 16일

심사(수정)일자: 2012년 3월 16일

게재확정일자 : 2012년 3월 23일

[†] Corresponding author

"본 논문은 본 학회 2012년도 춘계학술대회에서 선정된 우수논문입니다."

본 논문은 경기도의 경기도지역협력연구센터사업(GRRC 수원2012-B2, U-city 보안감시 기술협력센터) 및 한국연구재단 연구자지원사업(NRF-2012-003568)에서 지원하여 연구하였음.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

신경회로망을 이용한 패턴분류 및 인식에 관한 연구가 활발히 진행되고 있으며 그 중에서도 방사형 기저 함수를 이용한 신경회로망을 많이 연구하고 있다. 방사형 기저 함수 신경회로망은 고차원의 입-출력 형태를 갖는 클래스를 다루는데 유용하고 구조가 심플하여 데이터 전처리 및 클러스터링 방법과 최적화 알고리즘과 같이 서로 다른 분야에서 연구되고 있는 알고리즘과의 결합이 용이하다[1].

전처리기법에는 선형 및 비선형 특징추출 방법이 존재한다. 선형 특징추출방법에서 대표적으로 주성분 분석법(Principal Component Analysis; PCA)[2]과 선형판별 분석법(Linear Discriminant Analysis; LDA)[3]이 있으며 비선형 특징추출 방법은 기존의 선형특징 추출방법에 커널함수를 이용하여 비선형 부분공간의 매핑을 통해 데이터의 특

정을 추출방법이 있다.

클러스터링 알고리즘에는 K-Means 클러스터링[4] 및 Fuzzy C-Means[5] 그리고 Context Fuzzy C-Means[6] 클러스터링 알고리즘이 많이 사용되고 있으며 데이터의 유사성을 기반으로 데이터의 그룹화를 통해 보다 효율적인 데이터의 정보를 처리하는데 목적을 둔다. 일반적으로 이러한 정보는 신경회로망에서 활성화함수의 중심점 및 은닉층의 수를 결정하는데 큰 역할을 한다.

최적의 구조 및 파라미터를 동조하기 위한 최적화 알고리즘은 유전자 알고리즘(Genetic Algorithm; GA)[7]을 시작으로 입자 군집 최적화(Particle Swarm Optimization; PSO)[8], 차분 진화 알고리즘(Differential Evolution; DE)[9] 알고리즘과 같이 개체의 적자생존 및 집단의 행동 양식에 기반한 알고리즘들이 현재에도 활발히 연구 되고 있다.

본 연구에서는 신경회로망 입력층에 전처리 기법을 적용하여 입력변수의 정보 손실을 최소화한 저차원의 특징 데이터를 생성한다. 또한 신경회로망의 은닉층은 기존의 활성화함수 대신 FCM 클러스터링 알고리즘으로 구성되어 각 클러스터의 중심점과 데이터의 소속정도를 나타내는 소속행렬 값을 활성화함수의 적합도로 사용한다. 연결가중치는 상수항 대신 1차선형식을 사용하여 출력을 입력과 출력의 관계식으로 표현하였다. 최적의 분류기 설계를 위해 Artificial Bee Colony(ABC) 알고리즘을 이용하여 주성분 분석법 및 선형 판별 분석법의 고유벡터의 수 및 FCM 클러스터링 알고리즘의 퍼지화 계수를 동조한다.

2. 선형특징 추출기법

2장에서는 제안된 신경회로망 분류기에서 전처리부분으로 구성된 주성분 분석법과 선형판별 분석법에 대해 서술한다.

2.1 주성분 분석법

주성분 분석법은 대표적인 선형변환 특징추출 방법으로 데이터의 공분산행렬을 이용하여 구한 특징데이터의 차원이 실제 입력 데이터의 차원보다 작은 값이 되어 저차원의 특징을 추출한다. 주성분 분석법의 가장 큰 목적은 변화 후의 특징데이터가 변환전의 실제 데이터의 정보를 최대한 유지하도록 하는 것이다. 주성분 분석법 알고리즘은 다음과 같다[2].

[단계 1] 입력데이터 집합 X 의 평균 μ_x 공분산 $\sum x$ 를 계산한다.

$$\mu_x = \frac{1}{N} \sum_{i=1}^M x_i \quad (1)$$

$$\mu_x = \frac{1}{N} (X - M_x)(X - M_x)^T \quad (2)$$

[단계 2] 고유치 분석을 통해 공분산 $\sum x$ 의 고유치행렬 A 와 고유벡터행렬 U 를 계산한다. 식(4)와 같이 선형 판별 분석법의 고유치 방법과 동일하다.

$$\sum x \text{ or } S_w^{-1} S_T = [w_1, w_2, \dots, w_n] \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_n \end{bmatrix} [w_1, w_2, \dots, w_n]^T \quad (3)$$

[단계 3] 고유 값이 큰 순서로 k 개를 선택하여 대응되는 고유벡터를 변환행렬 $W = [w_1, w_2, \dots, w_k]$ 로 저장한다.

[단계 4] 특징 데이터 Y 을 구한다.

$$W^T X = Y \quad (4)$$

여기서 특징 데이터 Y 를 선형판별 분석법을 사용하여 새로운 저차원의 특징데이터를 생성한다.

2.2 선형판별 분석법

선형 판별 분석법(Linear Discriminant Analysis; LDA)은 클래스간 분산과 클래스내 분산의 비율을 최대화하는 방식으로 특징 추출을 목적으로 한다. 본 논문에서는 독립변환 접근법을 이용하여 전체 분산과 클래스 내 비율을 최대화하는 방식으로 특징 데이터를 구한다[3].

[단계 1] 전체 분산 S_T 와 클래스 내 분산 S_w 을 구한다.

$$S_T = \frac{1}{N-1} \sum_{i=1}^N (y_i - m)(y_i - m)^T \quad (5)$$

$$S_w = \sum_{j=1}^{class} \left\{ \frac{1}{N_c - 1} \sum_{i=1}^{N_c} (y_i - m_j)(y_i - m_j)^T \right\} \quad (6)$$

여기서, m 은 전체 입력데이터의 평균을 나타내며, $m_j(j=1, \dots, class)$ 는 각 클래스의 평균을 나타낸다. y 는 주성분 분석법의 특징 데이터를 나타낸다.

[단계 2] 식(7)의 비율을 최대로 하는 변환행렬 W 을 구한다.

$$J(W) = \arg \max_w \left| \frac{W^T S_T W}{W^T S_w W} \right| \quad (7)$$

여기서, W 는 $S_w^{-1} S_T$ 의 고유벡터를 열벡터로 가지는 행렬로 다음과 같이 식(3)과 같은 고유치 분석을 통해 구할 수 있다. 이 후 단계는 주성분 분석법의 [단계 3]과 [단계 4]와 동일하다.

주성분 분석법과 선형 판별 분석을 통해 차원이 축소된 특징 데이터를 가지고 다항식 방사형 기저 함수 신경회로망 분류기의 입력으로 사용된다.

3. 다항식 방사형 기저 함수 신경회로망

본 장에서는 다항식 방사형 기저 함수 신경회로망의 구조 및 은닉층을 구성하는 FCM 클러스터링 알고리즘에 대해 서술한다.

3.1 다항식 방사형 기저 함수 신경회로망 구조

제안된 다항식 방사형 기저 함수 신경회로망은 전처리 부분이 포함되어 총 4층으로 구성된다. 전처리 부분은 주성분 분석법과 선형판별 분석법의 서로 다른 두 특징추출 기법이 사용되어 초기 주어진 데이터의 차원을 두 번 축소된 특징 데이터를 생성한다. 생성된 특징데이터가 입력층을 거쳐 은닉층으로 들어오면 특징 데이터는 FCM 클러스터링을 통해 클러스터 개수만큼의 중심점과 데이터사이의 소속정도를 나타내는 소속값을 계산하고 이를 활성화함수의 적합도 개념과 동일하게 사용한다. FCM 클러스터링을 통해 계산된 적합도와 연결가중치를 이용하여 각 클래스 별 출력을 계산한다.

은닉층과 출력층 사이의 연결가중치는 1차 선형식으로 구성하였으며 식 (8)과 같다.

$$f_i(y') = a_{i0} + \sum_{k=1}^s a_{ik} y'_k \quad (8)$$

분류기의 최종 출력은 식 (9)과 같다.

$$\hat{q}(y') = \frac{\sum_{i=1}^c R_i(y') f_{iq}(y')}{\sum_{i=1}^c R_i(y')} \quad (9)$$

여기서, $q(q=1,...,class)$ 는 출력층의 노드를 가리키는 동시에 클래스를 나타낸다.

그림 1. 방사형 기저 함수 다항식 신경 회로망의 구조

Fig. 1. Architecture of Radial Basis Function Polynomial Neural Networks

3.2 FCM 클러스터링 알고리즘

FCM 클러스터링 알고리즘은 n 개의 입력변수의 집합을 c 개의 퍼지 그룹들로 분할하고 비유사성 측정의 목적함수가 최소가 되도록 각 클러스터의 중심점을 찾는 알고리즘으로 학습 과정은 다음과 같다[5].

[단계 1] 클러스터의 개수 $c(2 \leq c \leq n)$ 을 정하고 퍼지화계수

$m(1 < m < \infty)$ 을 선택한다. 초기 소속행렬(partition matrix) $U^{(r)}$ 을 초기화 한다. 알고리즘 반복 횟수를 $r(r=0, 1, \dots)$ 로 표시한다.

$$U^{(r)} = \left\{ u_{jl} \in [0, 1], \sum_{j=1}^c u_{jl} = 1 \forall l, 0 < \sum_{l=1}^N u_{jl} < n \forall j \right\} \quad (10)$$

[단계 2] 식 (12)을 이용하여 FCM 클러스터 중심 v 를 계산한다.

$$J(u_{jl}, v_j) = \sum_{j=1}^c \sum_{l=1}^N u_{jl}^m (d_{jl})^2 \quad (11)$$

여기서, u_{jl} 는 0과 1사이의 소속을 나타내는 정도의 값으로 $j(j=1, \dots, c)$ 번째 클러스터에 속해져 있는 y'_k 의 $k(k=1, \dots, n)$ 번째 데이터의 소속정도를 나타낸다. v_j 는 $j(j=1, \dots, c)$ 번째 클러스터 중심 벡터이다. m 은 소속행렬에서 애매함의 정도에 대한 영향을 나타내는 퍼지화 계수이다. 이 값은 $m \in [1, \infty)$ 와 같은 범위를 가지고 있다.

식 (11)의 목적함수를 최소화하기 위해서 먼저 v_j 와 u_{jl} 와 관련된 식의 목적함수를 다음과 같이 분화시켜야 한다.

$$v^{(r)} = \{v_{k1}^{(r)}, \dots, v_{kc}^{(r)}\}, v_{kj}^{(r)} = \frac{\sum_{l=1}^N (u_{jl})^m \cdot y'_{kl}}{\sum_{l=1}^N (u_{jl})^m} \quad (12)$$

$$u_{jl} = \frac{(1/\|y' - v_s\|^2)^{1/m-1}}{\sum_{j=1}^c (1/\|y' - v_j\|^2)^{1/m-1}} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{sl}}{d_{jl}} \right)^{2/(m-1)}} \quad (13)$$

식 (11)에서 주어진 목적함수를 만족하기 위하여 식 (12)과 식 (13)에 의해서 구해진 값들을 이용하여 각각의 클러스터 중심과 데이터와의 거리계산을 통해 새로운 소속행렬을 생성한다.

$$d_{jl} = d(y'_{kl} - v_{kj}) = \left[\sum_{j=1}^c (y'_{kl} - v_{kj})^2 \right]^{1/2} \quad (14)$$

[단계 3] 다음과 같이 새로운 소속행렬 $U^{(r+1)}$ 을 계산한다.

$$u_{jl}^{(r+1)} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{sl}^{(r)}}{d_{jl}^{(r)}} \right)^{2/(m-1)}} \quad (15)$$

[단계 4] 다음 식 (16)을 계산해서 만일 $\Delta > \epsilon$ 이면 $r=r+1$ 로 정하고 [단계 2]로 가서 다시 알고리즘을 반복 수행하고 그렇지 않고 $\Delta \leq \epsilon$ 이면 알고리즘을 종료한다. 여기서, ϵ 는 임계값이다.

$$\Delta = \|U^{(r+1)} - U^{(r)}\| = \max_{j,l} |u_{jl}^{(r+1)} - u_{jl}^{(r)}| \quad (16)$$

4. Artificial Bee Colony 최적화 알고리즘

본 장에서는 Artificial Bee Colony 최적화 알고리즘에 대해 설명하고 제안된 분류기의 최적화 방법에 대해 서술한다.

4.1 Artificial Bee Colony 최적화 알고리즘

Artificial Bee Colony(ABC) 알고리즘은 꿀벌 집단의 먹이를 수집하는 행동양식에서 아이디어를 얻은 최적화 알고리즘으로 2005년 Karaboga에 의해 소개되었다. ABC 최적화 알고리즘은 일 벌, 탐색 벌, 그리고 스카우트 벌로 구성된 세 개의 연산자를 사용하여 탐색을 수행하며 알고리즘은 다음과 같다[10].

[단계 1] 초기 파라미터 설정 및 탐색공간 내에서 임의의 지역해를 생성한다.

$$D_i(t) = [x_1(t), x_2(t), \dots, x_n(t)] \quad (17)$$

$$NP(t) = [D_1(t), D_2(t), \dots, D_s(t)] \quad (18)$$

[단계 2] 식(19)을 이용하여 일 벌(Employed Bee)를 s개 생성하고 목적함수 평가 및 적합도를 생성한다.

$$v_{ij}(t+1) = x_{ij}(t) + \phi_{ij}(x_{ij}(t) - x_{kj}(t)) \quad (19)$$

여기서, ϕ 는 [-1 1]의 랜덤상수이며, i 와 k 는 개체의 번호를 나타내고, $i \neq k$ 를 만족한다.

[단계 3] 식 (20)를 이용하여 적합도를 [0, 1] 사이의 확률값으로 변환

$$p_i = \frac{fit_i}{\sum_{j=1}^s fit_j} \quad (20)$$

여기서, i 와 j 는 개체의 수를 나타낸다.

[단계 4] 식(20)과 확률값 p_i 를 이용하여 정찰 벌(Onlooker Bee)을 s개 생성하고 목적함수를 평가한다.

[단계 5] 스카우트 벌(Scout Bee)을 통해 제한(Limit) 조건을 만족하는 해를 판별. 만약 조건을 만족하는 해는 제거되고 새로운 해를 임의로 생성한다.

[단계 6] 종료조건을 만족할 때까지 [단계 2]~[단계 5]를 반복 수행한다.

일벌은 탐색공간 내에서 전역탐색을 수행하며 탐색 벌은 적합도가 우수한 해의 위치에서 보다 많은 탐색을 수행하는 지역탐색의 역할에 비중을 두고 있다. 스카우트 벌의 경우 세대를 거쳐 적합도가 가장 낮은 해를 찾아 제거하고 새로운 해를 생성하여 보다 우수한 해를 저장하는 역할을 한다.

4.2 ABC 알고리즘을 이용한 최적화 방법

제안된 분류기의 성능은 주성분 분석법과 선형판별 분석법의 고유벡터의 수 및 FCM 클러스터링 알고리즘의 퍼지화 계수와 같은 파라미터에 의해 영향을 받는다. 따라서 이러한 파라미터들의 최적의 값을 찾고자 ABC 최적화 알고리즘을 사용하였다.

본 연구에서는 전처리과정 및 FCM 클러스터링 알고리즘이 분류기 성능사이의 연관성을 분석하고자 개체의 파라미터를 그림 2와 같이 두 개로 나누어 각각 실험하였다.

퍼지화 계수는 1~5사이의 탐색범위를 가지고 있으며, 주성분 분석법의 고유벡터의 수는 최소 두개부터 초기 주어진 데이터의 최대 차원의 수만큼의 탐색범위를 갖는다. 선형판별 분석법의 고유벡터는 최소 두 개부터 주성분 분석법을 통해 얻어진 특징데이터의 최대 차원의 수만큼의 탐색범위를 갖는다.

Case I은 데이터의 차원축소만을 통한 분류기의 성능을 관찰하며 이 때 퍼지화 계수는 2로 고정한다. Case II는 데이터의 차원축소뿐만 아니라 퍼지화 계수를 동조하여 성능을 분석 및 Case I 및 최적화를 적용하지 않은 분류기와의 성능을 비교한다.

식(21)은 분류기의 패턴분류율을 나타내는 동시에 ABC 최적화 알고리즘의 목적함수가 된다. 학습 데이터만 가지고 목적함수가 최대가 되도록 최적화를 수행한다.

$$PCR[\%] = \frac{True}{N_{tr}} \times 100 \quad (21)$$

여기서, True는 분류 성공횟수를 나타내며, N_{tr} 은 학습 데이터의 수를 나타낸다.

5. 시뮬레이션 및 결과

제안된 분류기의 성능평가를 위해 Machine Learning (ML) 데이터를 사용하였으며 실험은 5fold cross validation(5fcv)을 사용하였다. 표 1은 실험에 사용한 데이터들의 입력변수, 데이터 및 클래스에 대한 정보를 나타낸다. 총 8개의 데이터를 사용하였으며 입력변수의 수는 최소 4개부터 최대 30개로 구성된 데이터를 사용하였다.

표 2는 ABC 최적화 알고리즘의 설정 파라미터를 나타낸다.

표 1. 실험에 사용된 데이터
Table 1. Data used in experiments

Data	No. of data	No. of input variables	No. of classes
Iris	150	4	3
WDBC	569	30	2
Pima	768	8	2
Wine	173	13	3
Balance	625	4	3
Liver	345	6	2
Vehicle	846	18	4
German	1000	24	2

표 2. ABC 알고리즘의 초기 설정 파라미터
Table 2. Initial setup parameters of ABC algorithm

Parameters	Values
No. of generations	60
No. of Populations	Employed Bee : 15 Onlooker Bee : 15
Limit	15
Random value[ϕ]	[-1 1]

표 3은 Case I 및 Case II 일 때의 최적화된 파라미터 및 테스트 데이터에 대한 분류기의 패턴분류율을 나타낸다.

표 3. Case I과 II 에서의 파라미터 및 패턴분류율
Table 3. Pattern classification rate and parameters in case of Case I and Case II.

(a) Case I

Data	Parameters			PCR [%]
	FC	No. of vectors of PCA	No. of vectors of LDA	
Iris	2	4	2	98.00
WDBC		30	26	96.84
Pima		8	3	77.47
Wine		13	9	98.86
Balance		4	3	90.73
Liver		5	4	68.12
Vehicle		18	16	79.31
German		19	19	75.80

(b) Case II

Data	Parameters			PCR [%]
	FC	No. of vectors of PCA	No. of vectors of LDA	
Iris	1.36	3	3	98.67
WDBC	1.28	21	20	97.37
Pima	4.34	6	4	77.47
Wine	3.75	12	9	98.86
Balance	4.75	4	3	90.56
Liver	1.36	5	4	70.43
Vehicle	2.51	16	15	79.67
German	4.93	22	22	76.30

FC : Fuzzification coefficient

표에서 보면 Case II일 때의 패턴분류율이 Balance 데이터를 제외하고는 Case I과 동일하거나 그보다 높은 분류율을 나타낸다. 가장 많은 차원이 축소된 데이터는 WDBC 데이터로 Case I의 경우 4개의 차원축소가 이루어졌지만 Case II에서는 10개의 차원축소에 불과하고 성능은 오히려 개선되었음을 알 수 있다.

표 4는 주성분 분석법을 통해 전처리를 한 방사형 기저 함수 신경회로망과 선형판별 분석법을 이용한 방사형 기저 함수 신경회로망의 패턴분류율을 보여준다.

표 4. 다른 분류기와의 성능비교
Table 4. Comparison of performance of other classifiers

Data	PCR [%]			D
	PCA-based classifier	LDA-based classifier	Proposed classifier	
Iris	97.33	98.00	98.67	-1
WDBC	95.58	96.67	97.37	-10
Pima	76.30	77.08	77.47	-4
Wine	95.40	98.86	98.86	-4
Balance	91.05	91.05	90.56	-1
Liver	73.04	66.09	70.43	-2
Vehicle	80.49	79.55	79.67	-3
German	76.30	76.20	76.30	-5

표에서 Iris, WDBC, Pima, Wine, 그리고 German 데이터의 경우 차원이 축소되었음에도 불구하고 주성분 분석법 및 선형판별 분석법을 각각 사용한 분류기보다 성능이 더 우수함을 알 수 있다. 표에서 D는 초기에 주어진 데이터의 차원 수와 제안된 분류기에서 전처리과정을 거친 특징 데이터의 차원 수와의 차이를 보여준다.

6. 결론 및 향후 연구

본 논문에서는 선형특징 추출기법을 이용한 다항식 방사형 기저 함수 신경회로망 분류기를 제안하였다. 신경회로망 입력층에 앞부분에 주성분 분석법과 선형판별 분석법을 이용하여 주어진 데이터의 차원 축소를 통해 특징데이터를 생성하고 이를 신경회로망의 입력으로 사용하였다. 신경회로망의 은닉층은 기존의 활성화함수 대신 FCM 클러스터링 알고리즘을 사용하여 소속행렬의 소속값을 적합도로 사용하였다. 또한 연결가중치는 1차 선형식을 사용하였다. 분류기의 최적설계를 위해 ABC 최적화 알고리즘을 적용하여 분류기를 구성하는 주성분 분석법과 선형판별 분석법의 고유벡터 수 및 FCM 클러스터링 알고리즘의 퍼지화 계수를 동조하였다.

References

- [1] S. K. Oh, W. D. Kim, and W. Pedrycz, "Polynomial based radial basis function neural networks(P-RBF NNs) realized with the aid of particle swarm optimization," *Fuzzy Sets and Systems*, vol. 163, no. 1,

- pp. 54-77, 2011.
- [2] H. Addi and L. J. Williams, "Principal component analysis," *Wiley Interdisciplinary Reviews: Computational Ststicstics*, vol. 2, no. 4, pp. 433-459, 2010.
 - [3] R. O. Duda, P. E. Hart, and D. H. Stork, *Pattern Classification*, Wiley Interscience 2nd, 2000.
 - [4] S. P. Lloyd, "Least squares quantization in PCM," *IEEE Tran. on Information Theory*, vol. 28, no. 2, pp. 129-137, 1992.
 - [5] J. C. Bezdek, *Pattern recognition with Fuzzy Objective Function Algorithm*, Plenum, New York, 1981.
 - [6] W. Pedrycz, "Conditional fuzzy clustering in the design of radial basis function neural networks," *IEEE Trans. Neural Networks*, vol. 9, no. 4, pp. 601-612, 1998.
 - [7] B. Gabrys and B. Ruta, "Genetic algorithms in classifier fusion," *Applied soft Computing*, vol. 6, pp. 337-347, 2006.
 - [8] J. Kennedy and R. Everhart, "Particle Swarm Optimization," *Proc. of IEEE International Conference on Neural Networks*, vol. 4, pp. 1942-1948, 1995.
 - [9] R. Storn, K. V. Price, "Differential Evolution-a fast and efficient heuristic for global optimization over continuous spaces," *Journal of Global Optimization*, vol. 11, pp. 341-359, 1997.
 - [10] D. Karaboga and B. Basturk, "Artificial bee colony optimization algorithm for solving constrained optimization problems," *LNAI4529 (IFSA 2007)*, pp. 789-798, 2007.

저 자 소 개

김옥동(Wook-Dong Kim)

2009년 : 수원대학교 전기공학과 공학사

2011년 : 수원대학교 전기공학과 공학석사

2011년~현재 : 수원대학교 전기공학과 박사과정

관심분야 : Fuzzy Inference, Neural Network, Evolutionary Optimization, Granular Computing

Phone : +82-31-222-6544

E-mail : wdkim@suwon.ac.kr

오성권(Sung-Kwun Oh)

1981년 : 연세대학교 전기공학과 공학사

1983년~1989년 : 금성산전연구소

(선임 연구원)

1993년 : 연세대학교 전기공학과 공학박사

1996년~1997년 : 캐나다 Manitoba 대학 전기 및 컴퓨터 공학과

Post-Doc.

1993년~2004년 : 원광대학교 전기전자 및 정보공학부 교수

2005년~현재 : 수원대학교 전기공학과 교수

2002년~현재 : 대한전기학회, 제어로봇시스템학회, 퍼지 및 지능시스템학회 편집위원

관심분야 : Fuzzy System, Fuzzy-Neural Network, Automatic System, Advanced Computational Intelligence, Intelligent control.

Phone : +82-31-229-8162

E-mail : ohsk@suwon.ac.kr